

**PRETHODNO PRIPĆENJE****UDK 330.354:330.4>(4-12)***Mr. sc. Oriana Vukoja***ANALIZA FAKTORA RASTA ZEMALJA  
SREDNJE I ISTOČNE EUROPE\*****ANALYSIS OF GROWTH FACTORS IN  
CENTRAL AND EASTERN EUROPEAN COUNTRIES**

---

**SAŽETAK:** Vezano uz globalne integracijske trendove kojima je konvergencija dohodaka per capita nužan preduvjet za održivost, cilj je ovoga rada izvršiti analizu odrednica ekonomskog rasta u odabranim zemljama srednje i istočne Europe. Nakon empirijskog prikaza relevantnih istraživanja rasta, u radu se nastavlja s ekonometrijskom analizom faktora rasta primjenom tehnike fiksnog panela. Rezultati takve analize, unutar uzorka od 8 odabranih zemalja srednje i istočne Europe u razdoblju od 1990. do 2003. godine, pokazuju da se rast u većoj mjeri zasnivao na čimbenicima koji ostaju izvan specifikacije modela rasta dosadašnjih relevantnih studija koje svoje oslonce nalaze u neoklasičnoj teoriji i novim teorijama rasta. Odnosno, proces transformacije u tržišno gospodarstvo u zemljama uzorka kreirao je specifično makroekonomsko okruženje unutar kojeg su i faktori rasta nespecifični za tržišna gospodarstva imali zapaženu ulogu u objašnjavanju varijance u stopama ekonomskog rasta.

**KLJUČNE RIJEČI:** faktori ekonomskog rasta, fiksni panel, tranzicija.

**ABSTRACT:** Regarding the global integration-oriented trends that take output per capita convergence as a necessary precondition for their sustainability, the aim of this paper is to analyze factors of economic growth in chosen countries of Central and Eastern Europe. After the empirical survey of relevant growth literature, the paper continues with econometric analysis using fixed panel technique. The results, for the sample of 8 Central and Eastern European countries over the time span 1990-2003, show that the economic growth was mostly based on factors staying outside the specification of relevant empirical growth models making use of the neoclassical and new growth theories. In other words, the transformation process into a market economy in the sample countries created a specific macroeconomic environment within which the growth factors not specific for market economies played a significant role in explaining the variance in economic growth rates.

**KEY WORDS:** factors of economic growth, fixed effect panel, transition.

---

\*Rad je dio istraživanja obavljenog za potrebe izrade magistarskog rada obranjenog 13. lipnja 2006. godine.

## UVOD

Suočeni s raširenim disproporcijama u raspodjeli svjetskog dohotka, ekonomisti su u svojim istraživanjima pokušali naći ključ problematiki konvergencije, definirajući faktore koji bi mogli utjecati na ekonomski rast. Pa ipak, napor koji se čini kako bi se poboljšalo razumijevanje pokretača ekonomskog rasta i blagostanja, zapravo je neobično mali. Razlog je tome nemogućnost simplifikacije stvarnosti do razine gdje bi teoretski okvir imao neku sveobuhvatniju objasnidbenu moć. Ujedno, s empirijske strane, koja u pravilu nije ni imala za svrhu priklanjanje određenom teorijskom modelu već je pokušavala iz niza varijabli izdvojiti one značajne koje bi mogle za barem nekoliko postotaka povećati stope rasta, javlja se problem dostupnosti i pouzdanosti podataka.

Vezano uz globalne integracijske trendove kojima je konvergencija dohodaka per capita nužan preduvjet za održivost, cilj je ovoga rada izvršiti detaljnu analizu odrednica ekonomskog rasta u odabranim zemljama srednje i istočne Europe. Krenulo se od hipoteze da se, iako je ekonomski rast u analiziranim zemljama uvjetovan stanjem političke i ekonomske strukture, faktori rasta navedenih zemalja bitno ne razlikuju od faktora koji su identificirani kao statistički relevantni u zemljama okruženja. Ujedno, pretpostavilo se da će integracijski procesi imati pozitivne efekte na blagostanje analiziranih zemalja, naravno, ukoliko se uspiju svladati razvojni izazovi, dok će stabilnost integracije biti uvjetovana dinamikom rasta i realnom konvergencijom među zemljama članicama. Da bi se testirale hipoteze i ostvarili ciljevi istraživanja, korištene su ekonometrijske metode koje omogućuju precizniju kvantifikaciju rezultata poput panel analize te analize vremenskih serija.

Prvo je poglavlje dalo kratak pregled dosadašnjih empirijskih istraživanja vezanih uz analizu faktora rasta. Empirijske analize nisu dale jednoznačne odgovore niti tajne recepte uspjeha, ali su ukazale na odrednice rasta koje su se potvrdile kao signifikantne na većem uzorku zemalja. U drugom je poglavlju učinjena ekonometrijska analiza faktora rasta u odabranim zemljama srednje i istočne Europe. Prije negoli se krenulo na interpretaciju rezultata, napravljen je prikaz problema vezanih uz ekonometrijsko modeliranje rasta kao i ograničenje koje on nameće. Faktori rasta odabranih zemalja srednje i istočne Europe u razdoblju od 1990. do 2003. godine analizirani su primjenom tehnike fiksnog panela koja iskorištava varijacije u vremenskoj dimenziji za dobivanje efikasnijih procjenitelja i iz manjeg broja opservacija. Tom se tehnikom donekle zaobilaze problemi vezani uz ispuštene varijable kao i uz heterogenost.

## 1. EMPIRIJSKA ISTRAŽIVANJA RASTA

Ovo poglavlje predstavlja svojevrtni osvrt na postojeće empirijske dokaze kako bi se utvrdile neke "stilizirane činjenice"<sup>1</sup>, odnosno regularnosti u podacima, te kako bi se eventualno utvrdila i usporedila primjenjivost teorijskih modela ekonomskog rasta.

<sup>1</sup> Kaldor (1961) prvi utvrđuje odrednice dugoročnog rasta u vidu 6 "stiliziranih činjenica" koje govore o sustavnom porastu kapitala i outputa po radniku kroz vrijeme, kao i o konstantnom povratu na kapital, Y/K omjeru, te konstantnim udjelima dohodaka proizvodnih faktora u ukupnom dohotku kroz vrijeme, te o razlikama u stopi rasta produktivnosti među zemljama u vremenu. Naknadno su navedene "stilizirane činjenice" opovrgnute raznim tehnikama analize vremenskih serija (Aghion-Howitt, 1992, p.9).

Easterly i Levine (2001) dokumentiraju 5 "stiliziranih činjenica" ekonomskog rasta na uzorku od 64 zemlje unutar perioda 1980-1992. Prva dokazuje da je neoklasični "rezidual", a ne akumulacija faktora, zaslužan za razlike u razinama i stopama rasta dohotka među zemljama. Druga je da u dugom roku ne dolazi do uvjetovane konvergencije već do divergencije. Treća stilizirana činjenica tvrdi da dok je akumulacija faktora ustrajan fenomen, rast nije te tako staze rasta među zemljama znatno variraju. Četvrta govori o visokoj koncentraciji ekonomskih aktivnosti gdje proizvodni faktori odlaze u najbogatija područja. Peta stilizirana činjenica vezana je uz nacionalne politike za koje se tvrdi da su povezane s dugoročnim ekonomskim rastom.

No, ako se u obzir uzme kompleksnost tematike rasta koja ne dozvoljava postavljanje sveobuhvatnog modela koji bi bio dovoljno dobar odraz stvarnosti, tada niti ne čudi što, u pravilu, empirijski modeli kojima se objašnjava zavisna varijabla stopa ekonomskog rasta, ne počivaju niti na jednom teorijskom modelu. Odrednice dugoročnog rasta koje ujedno predstavljaju i točku razilaženja na teorijskoj razini, u pravilu se utvrđuju ad hoc iz šireg uzorka varijabli, stoga će se paralela između teorije i empirije povlačiti samo tamo gdje bude relevantno. Cilj je utvrditi koji faktori određuju raznovrsnost stopa rasta među zemljama te koje mjere ekonomske politike efikasno utječu na rast.

Suvremeni pristup empirijskoj analizi rasta počiva stoga na regresijskoj analizi koja pokušava definirati dugoročni rast kao funkciju svih varijabli uzorka baziranih na raspoloživim podacima. Među najcitiranijima, koji su se bavili cross-country analizom pri traženju signifikantne korelacije između dugoročne prosječne stope rasta realnog BDP-a per capita i niza strukturnih varijabli i varijabli instrumenata ekonomske politike, zasigurno je Barro (1991). Navedeni je autor koristio regresijsku jednadžbu oblika:

$$y_{i,t,T} = \alpha + \beta' X_{it} + \epsilon_{it} \quad (1)$$

gdje je  $X_{it}$  vektor varijabli koje se smatraju odrednicama dugoročnog rasta. One su uključivale osnovne teorijske odrednice rasta, poput investicija u istraživanje i razvoj (R&D), investicija u fizički kapital, proxy varijabli za ljudski kapital, stope rasta stanovništva kao i instrumente ekonomske politike, poput fiskalnih deficita i inflacije te indikatore otvorenosti sive ekonomije, političkih nestabilnosti i sl.

Barro i Sala-i-Martin (1995) koriste cross-country analizu na uzorku 90 zemalja u razdoblju 1965.-1985., te pokazuju da je prosječna stopa rasta BDP-a per capita pozitivno korelirana s razinom stečenog obrazovanja (kao referentnu točku autori koriste srednjoškolsko obrazovanje), s udjelom investicija (privatnim i javnim) u BDP-u, s uvjetima trgovine te s očekivanom duljinom životnog vijeka, dok je ista negativno korelirana s udjelom državne potrošnje u BDP-u. Iako se iz njihove analize može izvući zaključak da strukturne varijable koje nisu naglašene kao odrednice dugoročnog rasta u Solow-Swan modelu, imaju jak utjecaj na mogućnost rasta pojedine ekonomije, treba imati na umu i povratni efekt rasta na navedene ekonomske varijable. Tako je vrlo vjerojatno da će se, kako pojedina zemlja postaje razvijenija, veći dio BDP-a investirati i u fizički kapital i u obrazovanje, što ujedno predstavlja problem obrnute kauzalnosti (vidjeti više u 1.1).

No, čak i kada se utvrdi kauzalnost između odabranih varijabli i dugoročne stope rasta, i dalje ostaje pitanje robusnosti<sup>2</sup> te veze. Levine i Renelt (1992) tako testiraju velik broj varijabli koje su bile središtem istraživanja raznih studija o rastu. Koriste Leamerovu

<sup>2</sup> Kriterij robusnosti pokazuje koliko je signifikantnost varijable u modelu osjetljiva na promjene nezavisnih varijabli.

*extreme-bounds analysis* na uzroku 119 zemalja u periodu 1960.-1989. kako bi provjerili da li se teorijom predviđen smjer i statistička signifikantnost pojedine varijable mijenjaju kada se izmijeni uvjetovani set varijabli u regresiji; ako pretpostavimo da je varijabla robusna, odgovor bi trebao biti ne. Za većinu varijabli koje su korištene u regresijskoj analizi među zemljama, autori nalaze da ne vrijedi kriterij robusnosti. Pozitivnu i robusnu vezu nalaze između prosječne stope rasta i prosječnog udjela investicija u BDP-u te između prosječnog udjela investicija i trgovine u BDP-u. Naglašavaju kako se pozitivna korelacija između rasta i udjela izvoza u BDP-u ne može koristiti kao mjera međuovisnosti spomenutih varijabli per se, jer se gotovo isti rezultati dobiju i kada se koristi udio uvoza ili udio trgovine u BDP-u. Utvrđuju postojanje uvjetovane konvergencije među zemljama u slučaju kada regresijska jednadžba sadrži i varijablu koja aproksimira efekt ljudskog kapitala (uvjetovana robusna negativna korelacija početnog dohotka i prosječne godišnje stope rasta), ali njihovi nalazi upućuju da se brži rast siromašnijih nije bazirao isključivo na povećanju domaće štednje i međunarodnih priljeva kapitala, budući da autori za odabrane zemlje navedenog perioda dokazuju nerobusnu vezu između početnog dohotka i prosječnog udjela investicija u BDP-u.

Postoje i drugi problemi pri empirijskoj analizi, pa tako mnogi autori naglašavaju raširenu heterogenost među zemljama koja dovodi u pitanje relevantnost studija koje u isti model rasta stavljaju afričke i OECD zemlje. Durlauf i Johnson (1995) tvrde da se linearni regresijski model ne može koristiti jednoznačno za sve zemlje već se mora učiniti razlika među parametrima s obzirom na specifičnosti vezane uz pojedine ekonomije. Oni koriste CART metodu (engl. *classification and regression trees*) kako bi istražili nelinearnosti u procesu rasta koje impliciraju postojanje višestrukih *steady-state* staza rasta. CART procedura svrstava zemlje u podskupine koje se ponašaju u skladu s linearnim modelom rasta baziranom na Solowljevima varijablama. Tako postoje podskupine zemalja prema dohotku - zemlje s niskim, srednjim i visokim dohotkom. Zemlje sa srednjom razinom dohotka naknadno se grupiraju još i prema niskoj ili visokoj razini pismenosti. Autori testiraju nultu hipotezu o zajedničkom režimu rasta koristeći razinu dohotka per capita i stopu pismenosti (kao proxy ljudskog kapitala) kao indikatore razvojne razine. Dolaze do rezultata da ne postoji globalna konvergencija te prihvaćaju alternativnu hipotezu o postojanju višestrukih konvergencijskih klubova. Preciznije, autori nalaze dokaze konvergencije za zemlje koje pripadaju srednjoj dohodovnoj grupi, a imaju visoku razinu pismenosti, te za zemlje s niskim dohotkom, dok se dokaz konvergencije za zemlje s visokim dohotkom ne može naći<sup>3</sup>. Autori naglašavaju kako treba imati na umu i važnost tzv. društvenog kapitala u ekonomskom rastu koji uključuje kulturološke norme i vrijednosti poput stava prema radu i zaštiti vlasničkih prava.

Do sličnih zaključaka dolazi i Tan (2004) koji, pokušavajući identificirati podskupine zemalja za koje vrijedi zajednički model rasta GUIDE procedurom (engl. *generalized, unbiased interaction detection and estimation*), nalazi snažne dokaze kako mjere institucionalne kvalitete i etničke podijeljenosti definiraju konvergencijske klubove te nešto slabije dokaze da zemljopisna predodređenost utječe na divergenciju među zemljama. Durlauf i Quah (1998) također naglašavaju kako linearne regresije koje podrazumijevaju zajedničke parametre, nisu prikladan način za istraživanje novih teorija rasta te da takve regresije neće moći razlikovati modele višestrukih ravnoteža od tradicionalnog Solow-Swan modela.

<sup>3</sup> Procijenjeni parametar ukazuje na divergenciju, ali je nesignifikantan.

U pravilu, 1990-ih godina područje ekonomskog rasta bilo je iznimno popularno područje istraživanja među ekonomistima te su nastale brojne studije koje su pokušale empirijom dati odgovore na pitanja koje je postavila teorija. Sinteza empirijskih nalaza može se naći u Durlauf, Quah (1998), Temple (1999), Durlauf, Johnson i Temple (2004), Sala-i-Martin (2002) i dr. Ono što slijedi u nastavku poglavlja, samo je kratki pregled ključnih faktora prema radovima koji su naišli na najveći odaziv šire publike.

### 1.1. Investicije i rast

Prema Solow-Swan modelu investicije nisu mogle utjecati na dugoročnu stopu rasta zbog efekta opadajućih prinosa, što implicira nepovezanost stope investicija i stope rasta. Mnogi su autori u svojim istraživanjima potvrdili pretpostavku opadajućih prinosa, između ostalih i Mankiw, Romer i Weil (1992), Sala-i-Martin (1996), Benhabib i Spiegel (1994), King i Levine (1993). Međutim empirija ukazuje i na suprotno – na robusnu korelaciju između stope investicija i stope rasta.<sup>4</sup> Problem koji nastaje kada se empirijski testira utjecaj stope investicija na rast, vezuje se uz pojavu endogenosti (vidjeti više u 2.1). Tako se, kako pojedina zemlja postaje razvijenija, sve se veći udio BDP-a investira i u fizički kapital i u obrazovanje, te se postavlja pitanje utječu li investicije na rast ili rast utječe na investicije. Utjecaj endogenosti je pogotovo jak kada su u pitanju strane direktne investicije budući da su one u pravilu usmjerene u zemlje koje su već na putu ekonomskog uspjeha ili idu u tom smjeru. (Temple, 1999, p.138). Kod investicija je nužno obratiti pažnju i na kvalitetu i isplativost projekata, što agregatne studije u pravilu ne pružaju.

### 1.2. Stopa rasta stanovništva i rast

Iako teorija pretpostavlja egzogeno danu stopu rasta stanovništva, očekuje se da će u stvarnosti prirodni prirast biti vezan uz faktore ekonomskog rasta. Empirija je pokazala da stope fertiliteta opadaju kako raste per capita dohodak, ali također da rastu za najsiromašnije zemlje. Becker, Murphy i Tamura (1990) nalaze objašnjenje pa tvrde da bi rast mogao utjecati na društvenu supstituciju ulaganja u kvantitetu djece u ulaganje u kvalitetu ljudskog kapitala, budući da bi s tehnološkim napretkom došlo do povećanja povrata na ljudski kapital. Tako bi zemlje s niskom razinom ljudskog kapitala imale velike obitelji i malo bi investirale u edukaciju svojih potomaka, i obrnuto. Galor i Weil (1996) naglašavaju kako razina dohotka može biti negativno korelirana sa stopom fertiliteta, što može dovesti do višestrukih ravnoteža od kojih neke predstavljaju tzv. "zamku siromaštva".

Što se tiče povratnog efekta rasta stanovništva na ekonomski rast, većina istraživačkih studija nalazi slabu negativnu korelaciju između rasta stanovništva i per capita dohotka. Uzrok je najvjerojatnije u smanjenju prosječnog ljudskog kapitala i omjera kapital-rad. No taj je utjecaj djelomično umanjen i za promjene u stopi participacije radne snage. Kako bilo, empirijski gledano, izostaju snažni negativni efekti povećanog rasta stanovništva na ekonomski rast koje predviđa neoklasična teorija (Temple, 1999, p.142).

---

<sup>4</sup> Vidjeti više u Rogers (2003) i Durlauf, Johnson i Temple (2004).

Snaga korelacije ujedno može aproksimirati udio kapitala u proizvodnoj funkciji.

Efekti veličine ekonomije bitan su pozitivan faktor u endogenim teorijama rasta jer veći broj stanovnika implicira i veći broj istraživača - pronalazača novih ideja, generatora tehnološkog napretka. No Jones (1995) tvrdi da su takvi zaključci u oštroj kontradikciji s empirijskim dokazima 20. stoljeća.

### 1.3. Ljudski kapital i rast

Mankiw, Romer i Weil (1992) u svojoj proširenoj verziji Solowljevog modela rasta s ljudskim kapitalom, prilikom empirijskog testiranja koriste cross-country analizu na 3 različita uzorka zemalja (zemlje koje nisu članice OPEC-a, zemlje srednje dohodovne skupine te OECD zemlje) za razdoblje 1960.-1985. Uz pretpostavku da su stopa štednje i stopa rasta stanovništva neovisne od šokova specifičnih za svaku pojedinu zemlju, došli su do sljedećeg zaključka - Solowljev model točno predviđa smjer utjecaja stope štednje i rasta stanovništva na varijablu *output per capita*, ali znatno umanjuje jačinu utjecaja. Razlozi su za to sljedeći: za danu stopu akumulacije ljudskog kapitala viša stopa štednje i niža stopa rasta stanovništva vode do više razine dohotka pa time i do veće akumulacije ljudskog kapitala. Uključivanjem proxy varijable za ljudski kapital procijenjeni efekt stope štednje i rasta stanovništva otprilike dolazi na razinu koja se i predviđa Solowljevom modelom. Autori ujedno pokazuju da je proizvodna funkcija oblika  $Y = K^{1/3}H^{1/3}L^{1/3}$  konzistentna s empirijskim nalazima njihova rada, što implicira elastičnost dohotka na stopu štednje od jedne polovine (za Solowljev standardni model ta je vrijednost jednaka 1). Uključivanjem varijable ljudski kapital u standardni Solowljev model autori su uspjeli objasniti 80% varijacije u razinama dohotka među zemljama, izuzimajući zemlje OPEC-a.

U kasnijim se radovima upućivalo na neke od nedostataka navedenog rada Mankiw, Romer i Weila. Benhabib i Spiegel (1994) tako na uzroku 78 zemalja pokazuju znatno manji doprinos ljudskog kapitala u objašnjenju stope rasta per capita dohotka. Njihovi rezultati upućuju na zaključak da ljudski kapital povećava rast preko mehanizma tehnološkog sustizanja te da je rast pozitivno koreliran sa stopom investicija.

U biti postoje neke konceptualne poteškoće s ljudskim kapitalom. Naime, često se kao proxy uzima stopa upisanih u srednje škole. Temple (1999) navodi nekoliko autora koji sugeriraju prosječan broj godina školovanja, kao bolju proxy varijablu, te navodi kao nužnost uključivanje efekta stjecanja radnog iskustva (p.139). U kvalitetu varijable ljudski kapital uključeni su i brojni drugi faktori koji potječu iz organizacije pojedinog društva kao i iz kvalitete osnovnih životnih uvjeta. Te je faktore vrlo teško obuhvatiti u nekom ekonometrijskom modelu, stoga je, u nedostatku sofisticiranih metoda, uloga dostupnijeg i boljeg obrazovanja na rast nedorečena.

### 1.4. Tehnologija, R&D aktivnosti i rast

Utjecaj tehnološkog napretka na rast u ekonomskoj se teoriji tumači iz dviju različitih perspektiva. Tehnologija je javno dobro raspoloživo svima uz jednake uvjete, što znači da se razlike u rastu mogu objasniti isključivo razlikama u razinama ljudskog i fizičkog kapitala, dok se diferencijacija, s obzirom na razinu tehnološkog napretka, uvodi pomoću multiplikativnog faktora početne razine tehnološke efikasnosti (Mankiw, Romer i Weil,

1992). S druge strane, novije teorije i dalje preuzimaju ideju javnog dobra budući da bi u pravilu, ako dovoljno dugoročno gledamo, sve zemlje morale imati pristup svim tehnološkim spoznajama u svijetu, no prema tim se teorijama rast može razlikovati među zemljama u ovisnosti od količine resursa koji se alociraju u istraživački sektor. Pojedini ekonomisti naglašavaju i utjecaj tzv. 'jaza ideja' kao ključnu determinantu razvojnog jaza. Po njima bi utjecaj klime i nekih kulturoloških specifičnosti mogao utjecati na stvaranje i transfer ideja među zemljama pa time i na stopu gospodarskog rasta.

Uloga povećanih istraživačkih aktivnosti čini dakle bit novih teorija rasta koje endogeniziraju tehnološki napredak. Empirijski, njihov je utjecaj na rast umanjen za mogućnost potpunog sagledavanja *spillover* efekata koji generiraju. No među ekonomistima postoji općeprihvaćena ideja većeg društvenog povrata na povećane istraživačke aktivnosti te se, čak i neovisno od njihova konačnog efekta na stopu rasta, R&D aktivnosti smatraju povoljnima za blagostanje.

Coe i Helpman (1995) pokušavaju utvrditi utjecaj stranih i domaćih R&D aktivnosti na ukupnu domaću produktivnost proizvodnih faktora na uzorku 21 OECD zemlje plus Izrael, u periodu 1971.-1990. Prema njihovim nalazima, strane R&D aktivnosti imaju znatan utjecaj na domaću produktivnost i to posebno u malim otvorenim ekonomijama jer međunarodna razmjena djeluje kao transmisijski mehanizam koji povezuje poboljšanja u produktivnosti domaće ekonomije s gospodarskim napretkom u zemljama trgovinskim partnerima. Direktna prednosti transmisijskog mehanizma očituju se u vidu spoznaja o novim tehnologijama, proizvodnim procesima, materijalima i organizacijskim metodama, dok indirektna prednosti proizlaze iz uvoza novih dobara i usluga koje su stvorene u zemljama trgovinskim partnerima.

Kritiku endogenim modelima rasta baziranim na R&D aktivnostima i ekonomiji ideja daje Jones (1995) kada empirijski testira njihovu valjanost. Jones zaključuje da za OECD zemlje stopa rasta u 40 godina nakon Drugoga svjetskog rata nije pokazivala nikakav konzistentan rastući trend, bez obzira na promjene u ekonomskim politikama koje su bile usmjerene na one ekonomske varijable koje potiču rast. U pogledu AK modela, empirija pokazuje da trajno povećanje stope investicija ni u kojem pogledu ne utječe na rast vječno već da se taj utjecaj gasi najkasnije nakon 8 do 10 godina. Što se tiče modela rasta koji tvrde da bi stopa rasta trebala rasti zajedno s povećanjem razine R&D aktivnosti, empirija je bila još nemilosrdnija. Rezultati ukazuju da višestruko povećanje broja znanstvenika i istraživača nije imalo utjecaj na relativno stacionarne stope raste. Autor kritizira način na koji se u tim modelima pretpostavlja da su prednosti istraživanja povezane s postojećom zalihom znanja u gospodarstvu, pogotovo ako se u obzir uzme utjecaj produktivnosti istraživanja koji je povezan s otvaranjem novih istraživačkih područja.

Međutim, varijacije u tehnološkom napretku i u rastu proizvodnih inputa same po sebi ne mogu u potpunosti obuhvatiti razlike u stopama rasta među zemljama. Postoje i nešto širi utjecaji čije se značenje ne smije zanemariti.

## 1.5. Državni sektor i rast

Privatna inicijativa imperativ je tržišnih ekonomija, stoga i ne čudi uvriježeno mišljenje da su ekonomski rast i slabija državna intervencija pozitivno korelirani. No, empirija o tom pitanju nije u potpunosti usuglašena. Levine i Renelt (1992), primjerice, utvr-

đuju kako korelacija rasta i državne potrošnje nije robusna. Barro (1991) na uzorku 98 zemalja u periodu 1960.-1985. utvrđuje kako povećana alokacija sredstava u neproduktivne državne usluge ima negativan utjecaj na per capita dohodak. Ako se pođe od osnovnog neoklasičnog modela, treba imati na umu da za veliki državni sektor, koji investira više nego što bi privatni sektor bio voljan uštedjeti i investirati iz danog dohotka, negativan utjecaj povećane državne potrošnje na rast može u potpunosti izostati (kao što je slučaj s velikim infrastrukturnim investicijama ili investicijama u obrazovanje).

### **1.6. Otvorenost ekonomije i rast**

Kada je riječ o ulozi otvorenosti u ekonomskom rastu, tada je primarni fokus na efekte realokacije resursa na agregatnoj razini. Da bi utvrdili razinu otvorenosti, istraživači koriste proxy varijable poput udjela trgovine u BDP-u ili tečajne premije na crnom tržištu. U pravilu većina rezultata pokazuje kako otvaranje ekonomije pogoduje ekonomskom rastu, iako uvjeti pod kojima je ta pretpostavka ispravna nisu posve jasni. Grossman i Helpman (1991) tvrde kako je otvorenost ekonomije povezana i s tokovima znanja te kako je njihov konačni utjecaj na rast teško razdvojiti. Naime, povećana međunarodna mobilnost znanja povećat će produktivnost istraživačkih napora što će u konačnici dovesti i do povećanja stope rasta. Otvorenost ekonomije poticajna je i za povećanje FDI-a (direktnih stranih investicija), ali njihov će priljev ovisiti o brojnim faktorima među kojima su i makroekonomska i politička stabilnost.

### **1.7. Institucionalni faktori**

Pitanje institucionalnog razvoja naišlo je na veliki interes istraživača u novije vrijeme. Pokušao se kvantificirati utjecaj društvenih, političkih i ekonomskih sloboda na rast dohotka per capita. Dobar institucionalan okvir zaštitom vlasničkih prava stimulira tehnološki napredak, a služi i kao pokretač investicija, dok s druge strane političke nestabilnosti imaju jak negativan utjecaj na ekonomski rast.

Rodrik (1998) pripisuje kolaps rasta u mnogim zemljama nakon 1970-ih društvenim konfliktima koji se očituju u povećanoj nejednakosti i etničkoj podijeljenosti te u slabim institucijama konflikt-menadžmenta, proxy kojih su indikatori kvalitete državnih institucija, vladavine zakona, demokratskih prava i društvene sigurnosne mreže. I Levine i Renelt (1992) nailaze na manji koeficijent udjela investicija u nestabilnim i ratom pogođenim zemljama u odnosu na druge sa znatno mirnijom političkom atmosferom.

### **1.8. Zaključno o empirijskim istraživanjima**

Empirija dakle jasno pokazuje da ne postoji jednoznačna odrednica rasta. Najrobusnija varijabla i najznačajnija odrednica rasta, ako je suditi prema empirijskoj analizi, početna je razina dohotka. Veza između ljudskog kapitala i rasta je slaba, ali su neke varijable – indikatori zdravstvenog stanja, poput očekivanog životnog vijeka, robusno povezane s ekonomskim performansama. Empirija ukazuje i da veličina države nije značajna varijabla, dok je kvaliteta države te tako neefikasne birokracije ili one koje uzrokuju makroeko-



nomske nestabilnosti, poput hiperinflacije, ekstremnih deficita, neravnoteža na deviznom tržištu i sl. mogu biti pogubne za rast. Institucije su se pokazale kao najznačajniji faktor. Vladavina prava, slobodna tržišta, zaštita vlasničkih prava i dr. sve su varijable sa signifikantnim povoljnim utjecajem na rast. (Sala-i-Martin, 2002, p. 47) Sukladno neoklasičnom pogledu, uz opasku da postoje višestruke ravnoteže, akumulacija fizičkog kapitala, veća otvorenost ekonomije i tehnološki napredak također su poticali brži rast. Pa ipak, ne može se ne primijetiti da je, neovisno od brojnosti i raznovrsnosti empirijske literature, vrlo mali pomak učinjen u primjenjivosti i relevantnosti dobivenih rezultata za ekonomsku politiku, barem ako je suditi prema kriteriju robusnosti.

## 2. ANALIZA FAKTORA RASTA

U kontekstu globalnih integracijskih trendova konvergencija dohotka per capita predstavlja preduvjet efikasnosti integracije. No, u cilju spoznavanja takve konvergencije nužno je definirati njene odrednice odnosno faktore koji utječu na dugoročni ekonomski rast pa time i na smanjenje disproporcija među zemljama. Stoga se i analizom u ovom radu pokušavaju utvrditi odrednice rasta analiziranih zemalja srednje i istočne Europe da se dobije odgovor na pitanje kako ubrzati proces konvergencije.

Važno je naglasiti da niti jedna ekonometrijska analiza ne može u potpunosti vjerodostojno prikazati proces rasta te da bi se deskriptivna analiza, koja obuhvaća i druge aspekte, poput kulturološkog, političkog i institucionalnog, trebala koristiti kao komplement. Pa ipak, ekonometrijska je analiza nužna kako bi se testirale hipoteze i utvrdila signifikantnost potencijalnih faktora rasta, što upućuje na preciznost koju parcijalna deskriptivna analiza u pravilu ne dopušta.

Prvi će dio ovog poglavlja stoga pokušati dati deskriptivan prikaz kretanja pojedinih ekonomskih varijabli stavljajući naglasak i na posebnost ekonomskih prilika u svakoj analiziranoj zemlji. Nakon takve, parcijalne povijesnodeskriptivne analize, krenut će se na ekonometrijsku analizu faktora rasta panel metodom kako bi se iz nešto uopćene perspektive sagledao doprinos svih relevantnih faktora na ekonomski rast svih zemalja uzorka.

Odabir zemalja sveo se na tranzicijske zemlje srednje i istočne Europe (CEE), koje su ili postale članicama Europske unije ili su započele pregovore za članstvo. Razdoblje obuhvaća niz od 1990 do 2003. godine. Podatci su prikupljeni iz baze Svjetske banke *World Development Indicators*, 2005. Vezano uz podatke treba naglasiti da se kod komparativne analize dohodovnih nejednakosti koristi metoda kupovne moći (PPP) kako bi se u obzir uzele ne samo tečajne već i cjenovne razlike među zemljama, s obzirom da je razina cijena u pravilu viša u bogatijim zemljama, pogotovo kad su u pitanju osnovne životne namirnice. Na taj način svaka jedinica PPP dohotka, mjerena tzv. međunarodnim dolarom, ima istu kupovnu moć u svim zemljama svijeta. Kada su u pitanju stope rasta društvenog dohotka, PPP podatci odražavaju realne, a ne nominalne promjene bazirane na prosjeku međunarodnih cijena, stoga Nuxoll (1994) tvrdi kako bi bilo idealno koristiti PPP podatke za razine, a nacionalne račune u domaćim valutama za stope rasta, "budući da domaće cijene odražavaju trade-off s kojim su ekonomski agenti zapravo suočeni". (Temple, 1999, p.119) Ovaj se rad priklonio tom stavu.

Kada je riječ o ekonometrijskom testiranju, jedna od osnovnih zamjerki, ona koja se nameće čak i laiku, je da svaki model predstavlja pojednostavljenu verziju stvarnosti.

Ekonometrijsko testiranje, jednako kao ni teorija, ne može dati idealan pregled stvarnosti, stoga je, prije negoli se krene u tehničku analizu, nužno naglasiti neke od nedostatka koje treba imati u vidu kada se interpretiraju rezultati.

## 2.1. Problemi ekonometrijskog modeliranja rasta

U narednih će se nekoliko stranica pokušati ukazati na neke od problema ekonometrijske analize koji su istaknuti u recentnoj literaturi. Većina je preuzeta iz preglednih članaka o rastu koje su autorizirali Durlauf i Quah (1998), Temple (1999) i Durlauf, Johnson i Temple (2004) te se u njima može naći detaljnija analiza.

Empirijska istraživanja u pravilu počivaju na utvrđivanju kauzalnosti među određenim varijablama. Kauzalnost je potvrđena ako jedinično povećanje nezavisne varijable povećava zavisnu varijablu za određeni iznos, uz uvjet da ne postoje druge varijable izvan modela koje bi na nju mogle utjecati. Stoga je i prema Gauss-Markovljevim uvjetima<sup>5</sup> jedna od ključnih pretpostavki OLS regresije nepovezanost nezavisne varijable modela i reziduala. Kada se Gauss-Markovljevi uvjeti naruše, procijenjeni parametri mogu biti nekonzistentni i pristrani. Da bi se potvrdila kauzalnost, potrebno je dakle pronaći egzogeni varijablu koja nije povezana niti s jednom drugom varijablom modela. No upravo se pri selekciji varijabli javlja problem budući da će uvijek postojati dio previđenih varijabli. To nas vodi do problema previđene (engl. unobserved) heterogenosti kao i do problema ispuštenih varijabli (engl. OVB = omitted variable bias).

Heterogenost parametara je česta primjedba vjerodostojnosti empirijskih rezultata vezanih uz rast jer se zemlje, osim po ekonomskom, razlikuju i po mnogim drugim aspektima uključujući i kulturološke, institucionalne i političke aspekte. Iako modeli koji počivaju na heterogenom uzorku zemalja imaju određenu objasnidbenu moć, u ovom su se radu pokušale uzeti u obzir regionalne karakteristike kako bi se barem donekle ublažila mogućnost dobivanja nekonzistentnih procjena. Ujedno, utjecaj heterogenosti donekle je eliminiran i upotrebom fiksnog panela koji koristi dummy varijablu za svaku pojedinu zemlju uzorka uzimajući u obzir efekte specifične za svaku zemlju.

Usko vezan uz navedeni problem je i problem nereprezentativnih opservacija u modelu koji predstavljaju tzv. *outliers*. U empirijskim studijama o rastu *outliers* vrlo često predstavljaju siromašne afričke zemlje u kojima je rast gotovo u potpunosti izostao. Za ekstremne vrijednosti takve se varijable mogu u potpunosti izbaciti iz modela, ali i dalje ostaje problem njihove pravilne detekcije. U ovom se radu pretpostavlja da ne postoje značajni *outliers* za odabrani uzorak zemalja.

Problem ispuštenih varijabli (*OVB*) nastaje ako pri specifikaciji modela previdimo neku bitnu nezavisnu varijablu koja je korelirana s drugim varijablama u modelu. U toj će situaciji, nakon što provedemo regresijsku analizu, i dalje postojati veza između varijabli i reziduala modela. Navedeni problem opisuje ono što je poznato pod nazivom endogenost modela. Dodatni uzrok endogenosti je i obrnuta kauzalnost kada postoji mogućnost da zavisna varijabla povratno utječe na nezavisnu varijablu modela. Ako se radi o dinamičkom modelu, endogenost i mjerene pogreške mogu se eliminirati korištenjem instrumen-

<sup>5</sup> Postoje četiri Gaus-Markovljeva uvjeta za precizne OLS procjenitelje: 1.  $E(u_i)=0$ , 2.  $\sigma^2 u_i = \sigma^2 u$  za sve  $i$  (homoskedastičnost), 3.  $\sigma^2 u_i u_j = 0$ , 4. Nezavisne varijable su nestohastične (snažnija regulacija) ili imaju slučajnu komponentu, ali nisu s njom korelirane (slabija regulacija).

talnih varijabli gdje su kao instrumenti korišteni vremenski lagovi nezavisnih varijabli.<sup>6</sup> No, dinamički je panel koristan za modeliranje tranzicijske dinamike, dok se odrednice dugoročnog rasta mogu definirati i iz statičnog panel modela. U prilog statičnog panela u odnosu na dinamički ide i činjenica da bi prisutnost heterogenosti u situaciji kada su nezavisne varijable serijski korelirane dovela do nekonzistentnih procjena, kao što su ustvrdili Pesaran i Smith. (Temple, 1999, p.127)

U osnovi je svakog empirijskog rada vezanog uz rast i određena doza skepticizma prema kvaliteti korištenih podataka, gdje nepouzdanost državnih statistika i postojanje sive ekonomije predstavljaju samo neke od problema. Tu su još i problemi vezani uz procjenu ukupne zalihe kapitala te radnih sati i stope participacije radne snage. Summers i Heston (1996) tako tvrde da "stope participacije toliko variraju da čine BDP per capita nezadovoljavajućom proxy varijablom BDP-a po radniku". (Temple, 1999, p.118)

Problemi vezani uz ispuštene varijable (*OVB*) i pogriješke u mjerenju mogu se donekle riješiti korištenjem panel analize s fiksnim efektima gdje ne postoji mogućnost nepredviđene korelacije između nezavisnih varijabli i reziduala budući da fiksni efekti kontroli-  
raju za sve neuključene varijable koje su konstantne tijekom vremena, kao što je recimo početna razina efikasnosti. Iako se takvom empirijskom analizom dobivaju prosječni rezultati za odabrani skup zemalja, treba uzeti u obzir da je upravo cilj ovog istraživanja faktora rasta uopćiti zakonitosti vezane uz dugoročne performanse svih odabranih zemalja.

Postavlja se i dodatno pitanje primjenjivosti ekonometrijskih modela. Naime, ako se statističko značenje modela mijenja kako se mijenja skup odabranih varijabli, prikazivanje rezultata samo jednog modela bi, u najmanju ruku, bilo neadekvatno jer bi dalo nepotpunu sliku ignorirajući postojanje nesigurnosti koja se vezuje uz model i njegove rezultate.<sup>7</sup>

Iako se može činiti da ekonometrijsko testiranje i nije od neke velike pomoći, nikako ne treba ignorirati njegov doprinos, pogotovo ako se u obzir uzme recentna zavidna razina sofisticiranosti modela koji omogućuju preciznije rezultate. Veća dostupnost podataka o ekonomskim kretanjima u zemljama članicama uzorka također bi bila veliki korak naprijed.

## **2.2. Panel analiza faktora rasta odabranih zemalja srednje i istočne Europe**

U empirijskom dijelu korištena je panela analiza s fiksnim efektima. Uslijed nedostatka dužih vremenskih serija za zemlje uzorka, a s obzirom na navedene potencijalne probleme vezane uz regresijsku analizu među zemljama, odabir panel tehnike koja iskorištava varijacije u vremenskoj dimenziji za dobivanje efikasnijih procjenitelja i iz manjeg broja opservacija, čini se prihvatljivom alternativom. Tom se tehnikom donekle zaobilaze

<sup>6</sup> Ideju su i realizirali Caselli, Esquivel i Lefort (1996) koristeći instrumentalne varijable i GMM za procjenu dinamičkog panel modela.

<sup>7</sup> Levine i Renelt (1992) pokušavaju riješiti taj problem koristeći Leamerovu extreme-bounds analysis kako bi provjerili robustness parametara za velik broj empirijski testiranih varijabli vezanih uz rast. Sala-i-Martin (1997) pristupa problemu drugačije te, umjesto definiranja gornje i donje granice, analizira distribuciju procijenjenih parametara koristeći 62 moguće nezavisne varijable od kojih su 3 osnovne dok sve ostale dolaze u kombinaciji po 4.

problemi vezani uz problem ispuštenih varijabli (*OV*B) kao i uz heterogenost – barem kada su u pitanju početna stanja varijabli u modelu. Ujedno panel analiza rezultira preciznijim procjeniteljima (Verbeek, 2000).

Odabir fiksnog panela opravdan je i činjenicom da se pokušao procijeniti utjecaj i signifikantnost svih nezavisnih varijabli (uključenih i ne) na stopu rasta za sve analizirane zemlje uzroka. Iako se prosječnim vrijednostima ne može objasniti specifično iskustvo svake zemlje, treba imati na umu da i vrlo mali učinjeni korak može otvoriti put k nekom novom otkriću. Fiksni panel se i prema Hausmanovom testu<sup>8</sup> s 5% razinom signifikantnosti pokazao kao bolja metoda procjene parametara – ako Gauss-Markov uvjet slabije regulacije vrijedi, procjenitelj je asimptotično normalan. Isti je dobiven OLS metodom u regresiji devijacija od individualnih prosjeka nezavisnih varijabli. Za nezavisne varijable se pretpostavlja da su striktno egzogene, ali se ne nameće nužnost njihove neovisnosti od konstante koja uključuje efekte svih, pa i nepoznatih varijabli koje su specifične za svaku zemlju kroz vrijeme. Analiza bi ovom vrstom panela dala bolje rezultate kada bi se proširio period budući da svaka pojedina zemlja uzima po jedan stupanj slobode te na taj način umanjuje objasnidbenu moć modela.

Kako je zavisna varijabla prosječna godišnja stopa rasta BDP-a per capita (GGDPPC), nezavisne varijable korištene u analizi odabrane su između onih faktora rasta za koje je dokazan statistički utjecaj prema već provedenim empirijskim studijama o rastu i ekonomskoj teoriji. One se sastoje od udjela investicija u BDP-u (INV), prosječne godišnje stope rasta stanovništva (GPOP), udjela međunarodne razmjene u BDP-u<sup>9</sup> (OPEN), čime se aproksimira efekt otvorenosti na rast, udjela države u BDP-u (GOV) te bruto upisanih u srednje škole<sup>10</sup> (SCHOLL2ND), što je u biti proxy za efekte ljudskog kapitala na rast (vidjeti Barro i Sala-i-Martin (1995)). Odabir kao takav, naravno, nije savršen jer, na primjer, stopa upisanih u srednje škole ne pokazuje ujedno i kvalitetu inputa ljudski kapital, dok je varijabla dohotka per capita, barem za tranzicijski period, upitna zbog mogućih pogrešaka u mjerenju.

### 2.1.1. Panel analiza s fiksnim efektima

U analizi se koristi sljedeći linearni regresijski model:

$$y_{it} = \alpha_i + \beta' x_{it} + \varepsilon_{it} \quad (1)$$

gdje  $i$  predstavlja jedinice promatranja, odnosno zemlje uzorka ( $i = 1, 2, \dots, N$ ;  $N = 8$ ), dok  $t$  predstavlja razdoblja ( $t = 1, 2, \dots, T$ ;  $T = 13$ ). Budući da je izabran model fiksnih efekata, parametar  $\alpha$  pokazuje efekte svih varijabli koje su specifične za  $i$ -tu zemlju, a ne variraju tijekom vremena. Parametar  $\beta$  mjeri parcijalne efekte  $x_{it}$  u periodu  $t$  za zemlju  $i$ , dok je  $x_{it}$   $k$ -dimenzionalni transponirani vektor koji će predstavljati odabrane faktore rasta, za koje se smatra da su striktno egzogeni, odnosno neovisni od termina pogreške relacije,  $\varepsilon_{it}$ .

Fiksni efektini uz pomoć *dummy* varijabli za svaku pojedinu zemlju pokazuju dakle i utjecaj izostavljenih nezavisnih varijabli koje nisu uključene u model a djelovale su na stopu rasta BDP-a per capita. Parametar  $\alpha$  ima negativan predznak za Češku, Mađarsku,

<sup>8</sup> Hausman test -  $H_0$ : Nema sistematične razlike u OLS i GLS procjeniteljima. Empirijska vrijednost  $\chi^2(5) = (b-B)'[(V_b - V_B)^{-1}](b-B) = 11.23$ , Prob> $\chi^2 = 0.0471$ .

<sup>9</sup>  $(Izvoz + uvoz)/BDP$

<sup>10</sup> Ukupno upisani neovisno o starosti u odnosu na stanovništvo srednjoškolske dobi.

Slovačku i Sloveniju. S druge strane, ono što se fiksnom panel analizom i pokušava objasniti su  $\beta$  parametri pojedinih varijabli koje su u prosjeku za sve analizirane zemlje imali utjecaj na stopu rasta BDP-a per capita. Prema regresiji postotno povećanje udjela investicija u BDP-u, ceteris paribus, povećava stopu rasta za 0.6%, postotno povećanje stope rasta stanovništva ima, ceteris paribus, negativan utjecaj na rast u iznosu od 0.2%, postotno povećanje udjela bruto upisanih u srednje škole, ceteris paribus, povećava stopu rasta za 0.2%, postotno povećanje udjela države u BDP-u, ceteris paribus, smanjuje stopu za 0.1%, dok otvorenost ekonomije ima pozitivan utjecaj na stopu rasta 0.02%, ceteris paribus.

**Tablica 1.** Panel analiza s fiksnim efektima

Dependent Variable: GGDPPC

Method: Panel Least Squares

Date: 12/05/06 Time: 21:25

Sample: 1990 2003

Cross-sections included: 8

Total panel (unbalanced) observations: 107

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-34.88981	15.89130	-2.195528	0.0306
INV	0.660639	0.176028	3.753029	0.0003
GPOP	-0.203525	0.532584	-0.382146	0.7032
SCHOOL2ND	0.235302	0.180232	1.305547	0.1949
GOV	-0.105643	0.239645	-0.440829	0.6603
OPEN	0.020226	0.030416	0.664979	0.5077

#### Effects Specification

Cross-section fixed (dummy variables)

	CROSSID	Effect
1	1	3.262978
2	2	2.809265
3	3	-4.001385
4	4	-1.222980
5	5	3.487414
6	6	1.939067
7	7	-4.386398
8	8	-1.950703

R-squared	0.203428	Mean dependent var	1.130967
Adjusted R-squared	0.101738	S.D. dependent var	5.523623
S.E. of regression	5.235107	Akaike info criterion	6.262108
Sum squared resid	2576.196	Schwarz criterion	6.586844
Log likelihood	-322.0228	F-statistic	2.000473
Durbin-Watson stat	0.940813	Prob(F-statistic)	0.032466

Iako smjer utjecaja naznačenih varijabli djeluje u skladu s predviđanjima, kada se primjene testovi signifikantnosti, kako pojedinih varijabli (*t* testovi) tako i čitavog modela (*F* testovi), situacija se značajno mijenja. Tako *t* testovi pokazuju visoku signifikantnost za varijablu udio investicija u BDP-u 0.1%, dok sve druge varijable nisu imale signifikantan udio u objašnjenju varijance zavisne varijable čak niti na razini 10%. Slični rezultati proizlaze i kada se sagledava moć svih nezavisnih varijabli zajedno u objašnjenju zavisne varijable stope rasta BDP- per capita. *F* test nalaže da objasnidbena moć modela nije signifikantna čak ni na razini 5% (tablica 1). Uzrok ovakvim rezultatima može biti tehničke prirode, razlog zbog čega se u idućoj sekciji krenulo na testiranje stacionarnosti, ali i u činjenici da su odabrane zemlje istočne i srednje Europe u analiziranom razdoblju prolazile kroz transformaciju k tržišnom modelu gospodarstva te su na njihove ekonomske performanse utjecale varijable koje nisu nužno uključene u neoklasični model rasta, pa čak niti u model rasta ostalih, manje ili više naprednih zemalja. Tako je vjerojatno da su za ekonomski rast navedenih zemalja veliko značenje imali politički, institucionalni i sociološki čimbenici.

## 2.2.2. Unit root test

Unit root test koristi se za analizu (ne)stacionarnosti vremenske serije pojedine varijable. U stacionarnim serijama šokovi su privremeni i njihov efekt nestaje tijekom vremena kada se serija vraća u svoju dugoročnu ravnotežu. Kada je u pitanju trend staza rasta dohotka per capita tada pretpostavljamo da ista nije stohastična, što bi empirijski značilo da je varijabla stopa rasta dohotka per capita trend stacionarna. Ako se unit root test odbaci za neke od zemalja u uzorku trend se u pravilu može potvrditi i za cijeli uzorak jer je manje vjerojatno da je proces stvaranja outputa toliko različit među zemljama da bi šokovi u jednim imali trajan, a u drugima privremen učinak. (Temple, 1999, p.119)

Ako trend stacionarnost postoji, a parametar trenda je signifikantan, možemo ga koristiti i kao aproksimaciju stope rasta po stazi rasta. Međutim, ako je promatrana serija podataka kraća od trajanja poslovnog ciklusa, onda nam unit root ne može dati konačan odgovor je li parametar trend stacionarnosti aproksimacija rasta potencijalnog dohotka ili rasta dohotka u uvjetima podzaposlenosti, što ukazuje na poslovni ciklus.

Da bismo utvrdili jesmo li u poslovnom ciklusu ili ne, koristimo unit root test za varijablu razine zaposlenosti. Razlog je tome što se za analizu odstupanja stope rasta i zaposlenosti od njihovih ravnotežnih razina određenih strukturom tržišta rada, u slučaju male otvorene ekonomije ne možemo pouzdati u NAIRU stopu inflacije na koju upućuje Philipsova relacija, budući da u njoj stopa inflacije ovisi i o cijenama uvoznih dobara. Naime, tržište rada male otvorene ekonomije može biti u ravnoteži i na razini zaposlenosti koja ne odgovara strukturnoj, ako je ostavljena mogućnost za tečajne manipulacije kako bi se želje sindikata i poslodavaca uskladile. Tako, na primjer, aprecijacija tečaja može pojeftiniti uvozne proizvode do te mjere da sindikati, za zemlje s visokom sklonošću uvozu, pristanu i na nižu realnu nadnicu te tako dovedu tržište rada u ravnotežu koja ne implicira nepromjenjivu stopu inflacije.

Pod nultom hipotezom da nema stacionarnosti potvrđujemo unit root. Za testiranje stacionarnosti u ovom je radu korišten Im, Pesaran i Shin (*IPS*) test s Phillips-Perron procjenom i dužinom *lag*-ova (engl. *lag* = vremenski pomak) određenom Akaike kriterijem (*AIC*). Rezultati za svaku pojedinu varijablu prikazani su u idućoj tablici.

Rezultati upućuju na trend stacionarnost varijable zaposlenosti, ali ne u razinama već u promjenama u stopi rasta. Budući da je otkrivena trend staza za promjene u stopi rasta, možemo zaključiti da se analizirane zemlje uzorka i dalje nalaze u poslovnom ciklusu, a ne na svojoj dugoročnoj *steady-state* stazi rasta, stoga ni parametar trenda ne možemo biti od veće koristi. Trend stacionarnost je potvrđena i za ostale nezavisne varijable modela kao i za zavisnu varijablu stopu rasta BDP-a per capita.

Unit root testovi utvrdili su trend stacionarnost prvog reda integracije, te stoga je potrebno diferencirati sve varijable korištene u regresiji da bi se izbjegao problem tzv. *spurious* regresije. Naime, potrebno je u regresiju uključiti varijable istog reda diferencijacije kako bi rezultati dali smislene rezultate, jer će u suprotnom rezidual biti nestacionaran u vremenu, što dovodi do rasta standardnih pogriješaka u beskonačno. Rezultat je neupotrebljiva regresijska analiza.

**Tablica 2.** Panel analiza s fiksnim efektima, diferencirane varijable

Dependent Variable: DGGDPPC				
Method: Panel Least Squares				
Date: 13/05/06 Time: 19:48				
Sample (adjusted): 1991 2003				
Cross-sections included: 8				
Total panel (unbalanced) observations: 99				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.181507	0.439191	2.690192	0.0086
DINV	0.376334	0.210408	1.788591	0.0772
DGPOP	-1.023320	0.302254	-3.385632	0.0011
DSCHOOL2ND	0.001102	0.130671	0.008433	0.9933
DGOV	0.436833	0.270158	1.616954	0.1096
DOPEN	-0.107928	0.038768	-2.783947	0.0066
Effects Specification				
Cross-section fixed (dummy variables)				
CROSSID	Effect			
1	1	0.270695		
2	2	0.066660		
3	3	0.186842		
4	4	-0.077966		
5	5	0.014442		
6	6	-0.064984		
7	7	0.332459		
8	8	-0.772995		
R-squared	0.210846	Mean dependent var		0.951607
Adjusted R-squared	0.100731	S.D. dependent var		4.525764
S.E. of regression	4.291772	Akaike info criterion		5.873130
Sum squared resid	1584.060	Schwarz criterion		6.213903
Log likelihood	-277.7199	F-statistic		1.914788
Durbin-Watson stat	1.907175	Prob(F-statistic)		0.043397

Čak niti s diferenciranjem regresijskih varijabli, objasnidbena moć odabranog modela, kao ni testovi signifikantnosti parametara, ne promijene se znatnije. U regresiji s diferenciranim varijablama (tablica 2) predznaci smjera ostaju isti kao i u prethodnoj, osim za varijable udjela države i otvorenosti ekonomije. Udio investicija u BDP-u ostaje signifikantan, ali na razini 10%, dok znatna promjena nastaje u varijabli rasta stanovništva koja sada postaje signifikantna na razini 0.2%, dok sve druge varijable i dalje signifikantno ne objašnjavaju varijancu zavisne varijable. F test ponovno ukazuje na nesignifikantnu objasnidbenu moć modela na razini 5%. Navedeni nalazi potvrđuju prethodni zaključak da se uzrok ovakvim rezultatima nalazi u činjenici da je transformacijski proces, u analiziranim zemljama, stvorio specifično makroekonomsko okruženje u kojem su u ekonomskom rastu značajnu ulogu odigrali politički, institucionalni i sociološki čimbenici.

### 3. ZAKLJUČAK

Što se dakle može zaključiti o odrednicama rasta u zemljama srednje i istočne Europe od početka transformacije njihovih gospodarstava u tržišni model pa do aktualnih okretanja europskim integracijskim trendovima? Razrada odgovora na ovo pitanje krenula je od empirijskog prikaza istraživanja rasta u drugom poglavlju. Empirija je jasno pokazala da ne postoji jednoznačna odrednica rasta, barem ako je suditi prema kriteriju robusnosti. Sukladno neoklasičnom pogledu, uz opasku da postoje višestruke ravnoteže, akumulacija fizičkog kapitala, veća otvorenost ekonomije i tehnološki napredak poticajno su djelovali na rast. Dokazana je i slaba veza između ljudskog kapitala i rasta. Veličina države nije se pokazala kao značajna varijabla, dok kvaliteta države jest. Institucije su se pokazale kao najznačajniji faktor.

Drugo je poglavlje tada krenulo na analizu faktora rasta u odabranim zemljama srednje i istočne Europe. Čak i uz vrlo visoku dozu entuzijazma za empirijsko modeliranje, morale su se naglasiti brojne prepreke na putu do krajnjeg cilja – modela koji bi mogao s apsolutnom preciznošću odrediti sve faktore i njihove udjele u stopi rasta. Kako je dugoročna stopa rasta teoretski koncept, diskusija o njenim odrednicama pokušala se svesti u okvire koji ne narušavaju praktične koristi danog istraživanja. Uzorak analiziranih varijabli sveo se na nekolicinu za koje su relevantna empirijska istraživanja pokazala signifikantan statistički utjecaj. Kao zavisna varijabla korištena je prosječna godišnja stopa rasta BDP-a per capita, dok su kao nezavisne varijable korištene udio investicija u BDP-u, prosječna godišnja stopa rasta stanovništva, udio međunarodne razmjene u BDP-u, udio države u BDP-u te postotak bruto upisanih u srednje škole. Pokazalo se da odabrani faktori rasta nisu mogli signifikantno objasniti varijancu u stopama rasta odabranih zemalja srednje i istočne Europe u razdoblju 1990.-2003. godine, što upućuje na zaključak da je rast određen političkim, institucionalnim i sociološkim čimbenicima koji su vrijedili u uvjetima transformacije. Ujedno korištenjem analize trend stacionarnosti vremenskih serija stope rasta BDP-a per capita i zaposlenosti došlo se do zaključka da se navedene zemlje još uvijek nalaze u poslovnom ciklusu.

Čak i nakon detaljne analize faktora rasta i dalje ostaje pitanje postojanja različitih vrsta rasta, koji će negdje donijeti blagostanje, a negdje povećanu nejednakost, što predstavlja izazov daljnjoj analizi za odabrane zemlje srednje i istočne Europe. Jedan od zanimljivih koraka u daljnjim istraživanjima bio bi i stvaranje poveznice između dugoročnog rasta potencijalnog outputa i poslovnih ciklusa. Ujedno, uključivanje efekata nesigur-



nosti, kao i strukturalnih promjena na ekonomski rast je zanimljivo i, kako teorijski tako i empirijski, nedovoljno istraženo područje koje bi moglo pružiti mnoštvo novih uvida u odrednice dugoročnog ekonomskog rasta.

## LITERATURA

1. Aghion, P. i Howitt, P. (1992) "A Model of Growth through Creative Destruction", *Econometrica*, 60(2): 323-351.
2. Barro, R. (1991) "Economic Growth in a Cross-Section of Countries", *The Quarterly Journal of Economics*, 106(2): 407-43.
3. Barro, R. J. i Sala-i-Martin, X. (1995) *Economic Growth*, Boston: McGraw Hill.
4. Becker, G. S., Murphy, K. M. i Tamura, R. (1990) "Human Capital, Fertility, and Economic Growth", *The Journal of Political Economy*, 98(5): S12-S37.
5. Benhabib, J. i Spiegel, M. M. (1994) "The Role of Human Capital in Economic Development: Evidence from Aggregate Cross-Country Data", *The Journal of Monetary Economics*, 34(2): 143-73.
6. Caselli, F., Esquivel G. i Lefort, F. (1996) "Reopening the Convergence Debate: A new Look at Cross-Country Growth Empirics", *The Journal of Economic Growth*, 1(3): 363-389.
7. Coe, D. T. i Helpman, E. (1995) "International R&D Spillovers", *The European Economic Review*, 39(5): 859-887.
8. Durlauf, S. N. i Johnson, P. A. (1995) "Multiple Regimes and Cross-Country Growth Behaviour", *The Journal of Applied Econometrics*, 10(4): 365-84.
9. Durlauf, S. N., Johnson, P. A. i Temple, J. R. W. (2004) "Growth Econometrics", *Vassar College Department of Economics Working Paper Series 61*.
10. Durlauf, S. N. i Quah, D. T. (1998) "The New Empirics of Economic Growth", *Centre for Economic Performance, Discussion Paper No. 384*.
11. Easterly, W. i Levine, R. (2001) "What Have We Learned from a Decade of Empirical Research on Growth? It's Not Factor Accumulation: Stylized Facts and Growth Models", *World Bank Economic Review*, 15(2): 177-219(43).
12. Galor, O. i Weil, D. N. (1996) "The Gender Gap, Fertility, and Growth", *The American Economic Review*, 86(3): 374-387.
13. Grossman, G. M. i Helpman, E. (1991) *Innovation and Growth in the Global Economy*, Cambridge, Mass.: The MIT Press.
14. Jones, C. I. (1995) "Time Series Tests of Endogenous Growth Models", *The Quarterly Journal of Economics*, 110(2): 495-525.
15. Kaldor, N. (1961) "Capital Accumulation and Economic Growth", in Lutz, F. A. & Hague, D. C. (Eds.), *The Theory of Capital* (pp.177-222), New York: St. Martin's Press.
16. King, R. G. i Levine, R. (1993) "Finance and Growth: Schumpeter Might be Right", *The Quarterly Journal of Economics*, 108(3): 717-737.

17. Levine, R. i Renelt, D. (1992) "A Sensitivity Analysis of Cross-Country Growth Regressions", *The American Economic Review*, 82(4): 942-63.
18. Mankiw, N. G., Romer, D., Weil, D. (1992) "A Contribution to the Empirics of Economic Growth", *The Quarterly Journal of Economics*, 107(2): 407-437.
19. Nuxoll, D. A. (1994) "Differences in Relative Prices and International Differences in Growth Rates", *The American Economic Review*, 84(5): 1423-1436.
20. Quah, D. T. (1996) "Twin Peaks: Growth and Convergence in Models of Distribution Dynamics", *The Economic Journal*, 106(437): 1045-1055.
21. Rodrik, D. (1998) "Where Did All the Growth Go? External Shocks, Social Conflict, and growth collapses", *NBER Working paper* 6350.
22. Rogers, M. (2003) "A Survey of Economic Growth", *The Economic Record*, 79(244): 112-135.
23. Sala-i-Martin, X. (1996) "The Classical Approach to Convergence Analysis", *The Economic Journal*, 106(437): 1019-1036.
24. Sala-i-Martin, X. (1997) "I Just Ran Two Million Regressions", *The American Economic Review*, 87(2): 178-83.
25. Sala-i-Martin, X. (2002) "Fifteen years of New Growth Economics: What Have we Learned?", in Loayza, N. & Soto, R. (Eds.), *Economic Growth: Sources, Trends, and Cycles* (pp.41-59), Santiago: Central Bank of Chile. Available at: <http://www.columbia.edu/cu/economics/discpaper/DP0102-47.pdf>
26. Tan, C. M. (2004) "No One True Path: Uncovering the Interplay between Geography, Institutions, and Fractionalization in Economic Development", *Tufts University Economics Working Paper No. 2005-12*.
27. Temple, J. R. W. (1999) "The New Growth Evidence", *The Journal of Economic Literature*, 37(1): 112-156.
28. Verbeek, M. (2000) *A Guide to Modern Econometrics*, Chichester: John Wiley&Sons Ltd.